



Skriftlig tentamen i **Undersökningsmetodik** (4,5 hp), ingående som moment 1 i kursen **Regressionsanalys och undersökningsmetodik, 15 hp.**

Skrivtid: 5 timmar

Hjälpmedel: Miniräknare utan lagrade formler eller lagrad text. Vidhäftade formel- och tabellblad (obs! vidhäftas endast de tabellsidor som behövs för den här tentamen).

Tentamensgenomgång och återlämning: måndagen den 22 januari, kl. 16.00 i B705.

Därefter kan skrivningarna hämtas på studentexpeditionen, plan 7 i B-huset.

Tentamen består av fem uppgifter som kan ge totalt 100 poäng. För betyget A gäller 90-100 p., för betyget B gäller 80-89 p., för betyget C gäller 70-79 p., för betyget D gäller 60-69 p., för betyget E gäller 50-59 p., för betyget Fx gäller 40-49 p. och för betyget F gäller 0-39 p. För detaljerade betygskriterier se kursbeskrivningen på kurshemsidan.

**För full poäng på en uppgift krävs fullständiga och väl motiverade lösningar.**

Uppgift 1: (20 poäng)

En population innehåller  $N = 5$  element

$$x_1 = 6, x_2 = 10, x_3 = 4, x_4 = 2, x_5 = 10$$

Ur denna population skall man göra ett obundet slumpmässigt urval (OSU) om  $n = 2$  element.

a). Beräkna samplingfördelningen för den stokastiska variabeln  $\bar{X}$ . (10 poäng)

b). Beräkna  $E(\bar{X})$  och  $V(\bar{X})$ . (10 poäng)

Uppgift 2: (30 poäng)

Uppgiften handlar om den lilla republiken Slovenien. För att bestämma en skattning av befolkningen 31 dec 2017 gjordes ett obundet slumpmässigt urval utan återläggning av 5 kommuner bland alla Sloveniens 50 kommuner. Man tog reda på den definitiva befolkningen vid denna tidpunkt i dessa kommuner och man hade total tillgång på motsvarande uppgifter på befolkningen år 2002 (den lilla republiken hade genomfört en folkräkning år 2002). Total i den lilla republiken uppgick befolkningen 31 dec 2002 till 1 964 tusentals personer (alltså 1 964 000 personer). Följande resultat erhöles, alla siffror i tusentals personer:

Kommun	31 dec 2002	31 dec 2017
Gorizia E	20	18
Sava C	58	60
Karst N	30	30
Mura W	10	12
Savinja S	20	22

- a). Beräkna kvotskattningen av den totala befolkningen i Slovenien 31 dec 2017 med befolkning 31 dec 2002 som hjälpinformation. (5 poäng)
- b). Beräkna den skattade variansen för kvotskattningen av den totala befolkningen i Slovenien 31 dec 2017 med befolkning 31 dec 2002 som hjälpinformation. (10 poäng)
- c). Beräkna ett 95%-igt konfidensintervall för den totala befolkningen i Slovenien 31 dec 2017 med hjälp av kvotskattningen. (5 poäng)
- d) Beräkna ett 95%-igt konfidensintervall för den totala befolkningen i Slovenien 31 dec 2017 med hjälp av den vanliga OSU-skattningen. (10 poäng)

**Uppgift 3:** (10 poäng)

När är kvotskattningen bättre än den vanliga OSU-skattningen? (10 poäng)

**Uppgift 4:** (30 poäng)

I den lilla republiken Slovenien vill man göra en undersökning för att ta reda på vilka utgifter för boende som studenterna vid Ljubljana universitet har i genomsnitt per månad (utgifter i svenska kronor). Populationen har stratificerats i tre stratum efter akademitillhörighet. En stickprovsundersökning genomfördes för  $n=300$  individer. Följande resultat erhöles då:

Stratum	$N_i$	$n_i$	$\bar{x}_i$	$s_i$
Handelshögskolan	1200	200	2825	300
Fakultet för humaniora, utbildning och samhällsvetenskap	1000	50	2400	290
Fakultet för Juridik, psykologi och socialt arbete	900	50	2700	320

- a). Beräkna ett 95%-igt konfidensintervall för den genomsnittliga boendekostnaden per månad. (10 poäng)

En statistiker tog del av undersökningen och undrade hur stickprovet hade allokerats. Det visade sig att det fanns finansiella medel för att göra om undersökningen.

- b). Från sin erfarenhet på detta område säger statistikern att standardavvikelseerna i populationen borde vara lika med  $\sigma_1 = 350$ ,  $\sigma_2 = 200$  och  $\sigma_3 = 300$ , där  $\sigma_i$  står för standardavvikelsen i stratum nummer  $i$ . Beräkna hur de trehundra observationerna ska allokeras i detta fall. (10 poäng)

En annan statistiker säger att det är rimligare att förutsätta att standardavvikelseerna är lika.

- c). Beräkna hur de trehundra observationerna ska allokeras i detta fall. (10 poäng)

**Uppgift 5:** (10 poäng)

Antag att vi vill skatta  $P$  = andelen som skulle rösta med regeringsalliansen om det vore val idag. Hur stort urval måste vi dra om vi skall göra ett OSU utan återläggning bland "Svenska folket 16 år och äldre" samt vill ha en felmarginal på högst 3 % och en konfidensgrad på 95 %? (10 poäng)

# Formelsamling undersökningsmetodik

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad \hat{\tau} = N\bar{X}$$

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} = \frac{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}}{n-1} = \frac{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}{n(n-1)}$$

Beräkning av stickprovsstorlek:

$$n \geq \frac{N\sigma^2}{D^2(N-1) + \sigma^2}$$

Stratifierat urval:

$$\bar{X}_{st} = \sum_{i=1}^L W_i \bar{X}_i \quad V(\bar{X}_{st}) = \sum_{i=1}^L W_i^2 V(\bar{X}_i) \quad \text{där } W_i = \frac{N_i}{N}$$

Optimal allokering:

$$n_i = n \frac{N_i \sigma_i}{\sum_{j=1}^L N_j \sigma_j}$$

Skattning av medelvärde samt proportion per element:

$$\bar{X}_{kvot} = \frac{\sum_{i=1}^n \tau_i}{\sum_{i=1}^n m_i} \quad \bar{X}_{VVR} = N \frac{\bar{\tau}}{M} \quad p_{kvot} = \frac{\sum_{i=1}^n a_i}{\sum_{i=1}^n m_i} \quad P_{VVR} = N \frac{\bar{a}}{M}$$

Punktskattning	Varians	Variansskattning	Varians	Variansskattning
OSU	m. å.	m. å.	u. å.	u. å.
$\bar{X}$	$\frac{\sigma^2}{n}$	$\frac{s^2}{n}$	$\frac{\sigma^2}{n} \left( \frac{N-n}{N-1} \right)$	$\frac{s^2}{n} \left( 1 - \frac{n}{N} \right)$
$\hat{\tau}$	$N^2 \cdot \frac{\sigma^2}{n}$	$N^2 \cdot \frac{s^2}{n}$	$N^2 \cdot \frac{\sigma^2}{n} \left( \frac{N-n}{N-1} \right)$	$N^2 \cdot \frac{s^2}{n} \left( 1 - \frac{n}{N} \right)$
$p$	$\frac{P(1-P)}{n}$	$\frac{p(1-p)}{n-1}$	$\frac{P(1-P)}{n} \left( \frac{N-n}{N-1} \right)$	$\frac{p(1-p)}{n-1} \left( 1 - \frac{n}{N} \right)$
$\hat{A}$	$N^2 \cdot \frac{P(1-P)}{n}$	$N^2 \cdot \frac{p(1-p)}{n-1}$	$N^2 \cdot \frac{P(1-P)}{n} \left( \frac{N-n}{N-1} \right)$	$N^2 \cdot \frac{p(1-p)}{n-1} \left( 1 - \frac{n}{N} \right)$

## Tillägg till formelsamling undersökningsmetodik

Skattning av  $\tau_X$ . Urval OSU

$$\hat{\tau}_{kvot} = \hat{R} \cdot \tau_Z = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^n z_i} \cdot \tau_Z$$

$$\hat{V}(\hat{\tau}_{kvot}) = N^2 \left( \frac{N-n}{nN} \right) \frac{\sum_{i=1}^n (x_i - \hat{R}z_i)^2}{n-1}$$

$$\sum_{i=1}^n (x_i - \hat{R}z_i)^2 = \sum_{i=1}^n x_i^2 + \hat{R}^2 \sum_{i=1}^n z_i^2 - 2\hat{R} \sum_{i=1}^n x_i z_i$$

Skattning av  $\mu_X$ . Urval OSU.

$$\hat{\mu}_{reg} = \bar{x} + b(\mu_Z - \bar{z})$$


$$b = \frac{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}{\sum_{i=1}^n (z_i - \bar{z})^2}$$

$$\hat{V}(\hat{\mu}_{reg}) = \left( \frac{N-n}{nN} \right) \left( \frac{1}{n-2} \right) \left[ \sum_{i=1}^n (x_i - \bar{x})^2 - b^2 \sum_{i=1}^n (z_i - \bar{z})^2 \right]$$

**TABELL 2.** Normalfördelningens kvantiler, standardiserad

$Z \in N(0, 1)$ . Vilket värde har  $z_\alpha$  om  $P(Z > z_\alpha) = \alpha$  där  $\alpha$  är en given sannolikhet.

Utnyttja även  $\Phi(-z) = 1 - \Phi(z)$  för  $P(Z \leq -z_\alpha)$ .



$\alpha$	$z_\alpha$
0,25	0,6745
0,10	1,2816
0,05	1,6449
0,025	1,9600
0,010	2,3263
0,005	2,5758
0,0025	2,8070
0,0010	3,0902
0,0005	3,2905
0,00025	3,4808
0,00010	3,7190
0,00005	3,8906
0,000025	4,0556
0,000010	4,2649
0,000005	4,4172

2



Stockholms universitet

Statistiska institutionen

# Rättningsblad

**Datum:** 09/01/18

**Sal:** Ugglevikssalen

**Tenta:** Undersökningsmetodik

**Kurs:** Regressionsanalys och undersökningsmetodik

**ANONYMKOD:**

UND-JKN-TBW

Jag godkänner att min tenta får läggas ut anonymt på hemsidan som studentsvar.

**OBS! SKRIV ÄVEN PÅ BAKSIDAN AV SKRIVBLADEN**

Markera besvarade uppgifter med kryss

1	2	3	4	5	6	7	8	9	Antal inl. blad
X	X	X	X	X					4 34
Lär.ant. 20p	<del>20p</del> 20p	10p	30p	10p					

POÄNG 90p	BETYG A	Lärarens sign. RC
--------------	------------	----------------------

UPPGIFT 1

1) 20p

$N = 5$        $n = 2$

I POPULATIONEN

$\mu = \frac{(6+10+4+2+10)}{5} = 6,4$

$\sigma^2 = \frac{(6-6,4)^2 + (10-6,4)^2 + (4-6,4)^2 + (2-6,4)^2 + (10-6,4)^2}{5} \Rightarrow$   
 $0,16 + 12,96 + 5,76 + 19,36 + 12,96 = 10,24$

a) Hur många urval kan vi dra?

$\binom{N}{n} = \frac{5!}{2!3!} = \frac{5 \cdot 4}{2} = 10$  R

R	Urval	$\bar{x}$	$S^2$
1	6,10	8	8
2	6,4	5	2
3	6,2	4	8
4	6,10	8	8
5	2,4	3	2
6	2,10	6	32
7	2,10	6	32
8	4,10	7	18
9	4,10	7	18
10	10,10	10	0
$\Sigma$		64	128
Medelvärde		6,4	12,8

$\bar{x} = \frac{6+10}{2} = 8$   
 $\bar{x} = \frac{6+4}{2} = 5$   
 Hur jag räknat  
 värdet  $\bar{x}$

$S^2 = \frac{(6-10)^2}{2} = 8$   
 $S^2 = \frac{(6-4)^2}{2} = 2$

Hur jag räknat  
 värdet  $S^2$

$\Rightarrow$

Svar på a)

Samplingfördelning för  $\bar{x}$

x	8	5	4	3	6	7	10	
P(x)	0,2	0,1	0,1	0,1	0,2	0,2	0,1	1

R

$$b) E(\bar{x}) = 8 \cdot 0,2 + 5 \cdot 0,1 + 4 \cdot 0,1 + 3 \cdot 0,1 + 6 \cdot 0,2 + 7 \cdot 0,2 + 10 \cdot 0,1 = 1,6 + 0,5 + 0,4 + 0,3 + 1,2 + 1,4 + 1$$

$$\Rightarrow \underline{\underline{6,4}} \quad R$$

$$V(\bar{x}) = (8-6,4)^2 \cdot 0,2 + (5-6,4)^2 \cdot 0,1 + (4-6,4)^2 \cdot 0,1 + (3-6,4)^2 \cdot 0,1 + (6-6,4)^2 \cdot 0,2 + (7-6,4)^2 \cdot 0,2 + (10-6,4)^2 \cdot 0,1 = 0,512 + 0,196 + 0,576 + 1,156 + 0,032 + 0,072 + 1,296 \Rightarrow \underline{\underline{3,84}} \quad R$$

Om vi sätter  $p = \frac{10,24}{2} \cdot \left(\frac{5-3}{5-1}\right) = 5,12 \cdot 0,75 = \underline{\underline{3,84}}$

Och vi kan se från uträkningen att våra  $\bar{x}$  värden i genomsnitt är lika stora

Med populationens medelvärde vilket innebär att våra  $\bar{x}$  värden är i genomsnitt

lika stora som populationens medelvärde.

Svar  $E(\bar{x}) = 6,4$   $V(\bar{x}) = 3,84$



2) ~~20 p~~ 20 p

UPPGIFT 2

OSU - U.Ä. n = 5 N = 50 Totalbefolkning <sup>2002</sup> 1964 tusen

a) Hjälpvariabel  $\sum_{i=1}^n z_i = 138$  (i tusentals)

Undersökningsvariabel  $\sum_{i=1}^n x_i = 142$  (i tusentals)

Kvotskattning =  $\hat{R} \cdot T_z = \frac{\sum_{i=1}^n x_i}{\sum_{i=1}^n z_i} \cdot T_z$

$\hat{R} = \frac{142}{138} = 1,028985507$

$T_z = 1964$  (i tusentals)

$\hat{T}_{kvot} = \frac{142}{138} \cdot 1964 = 2020,927536$  (i tusentals) R

Svar: Kvotskattningen av den totala befolkningen år 2017 är ungefär 2020,93 (i tusentals)

b)  $V(\hat{T}_{kvot}) = N^2 \left( \frac{N-n}{nN} \right) \frac{\sum_{i=1}^n (x_i - \hat{R}z_i)^2}{n-1}$

V behövs ställa upp följande tabell:

$x_i^2$	$z_i^2$	$x_i z_i$	$V(\hat{T}_{kvot}) = 50^2 \left( \frac{50-5}{50 \cdot 5} \right) \cdot \frac{12,45362}{5-1} =$ $2500 \cdot 0,18 \cdot 3,113405 \Rightarrow$ $14101,03225 \approx 1401$
324	400	360	
3600	3364	3480	
900	900	900	
144	100	120	
484	400	440	
$\sum 5452$	$\sum 5164$	$\sum 5300$	$\sum (x_i - \hat{R}z_i)^2 \Rightarrow$

$5452 + \left( \frac{142}{138} \right)^2 \cdot 5164 - 2 \cdot \left( \frac{142}{138} \right) \cdot 5300$

$\Rightarrow 5452 + 5467,7 - 10907,24638 \Rightarrow 12,45362$

Svar: Den skattade variansen blir 1401.

R

c) Konfidensintervall:

Vårt  $n$  är litet så vi kan inte förlita oss på CGS, vi får anta normalfördelning.

Felmarginalen:  $1,96 \cdot \sqrt{V(\bar{x}_{95\%})}$  1,96 pga  $Z_{95\%}$  från tabellen

$$1,96 \cdot \sqrt{1401} = 1,96 \cdot 37,42993454 = 73,36267171$$

$$2020,93 \pm 73,36267171$$

$$[1947,667328; 2094,292672]$$

R

Svar: Med 95% konfidens ligger det sanna värdet i intervallet ovan.

d) 95% -igt konfidensintervall:

$$\bar{x} = 28,4$$

$$s^2 = \frac{\sum x_i^2 - n \cdot \bar{x}^2}{n-1} = \frac{5452 - 5 \cdot (28,4)^2}{4} = \frac{5452 - 4032,8}{4}$$

$$= 354,8$$

$$\frac{354,8}{5} \left(1 - \frac{5}{50}\right) = 70,96 \cdot 0,9 \Rightarrow 63,864$$

$$28,4 \pm 1,96 \sqrt{63,864} \Rightarrow 28,4 \pm 15,66333114$$

$$[12,73666886; 44,06333114]$$

F

Svar: Med 95% konfidens ligger det sanna värdet i intervallet ovan. F

→ FEL METOD  
(SE FACIT)

## UPPGIFT 3

3) 10p

Kvotskattningen är bättre när vi har hjälpinformation tillgänglig. Hjälpinformationen dvs variabeln  $Z$  ska vara korrelerad med vår undersökningsvariabel  $X$ . Om  $X$  och  $Z$  är en rät linje genom origo så passar kvotskattningen bäst. Helst ska de vara starkt och positivt korrelerade för att skattningen ska bli bättre. Men om vi endast har en rät linje som inte går igenom origo passar regressionskattningen bättre.

Sammanfattningsvis är en kvotskattning att föredra när vi har en rät linje genom origo dvs de är korrelerade (starkt, positivt) över en vanlig OSU.

Korrelation kan vara mellan  $-1$  och  $1$  och mäter linjära samband.

Exempelvis; Om vi vill skatta en persons inkomst så kan utbildning vara en bra hjälpinformation, och när vi den blir betydligt bättre än vanlig OSU från hjälpinformation.

VÄND BLAD

⇒

# UPPGIFT 4

4) 30p

n=300

$N_i$	$n_i$	$\bar{x}_i$	$S_i^2$	$w_i$
1200	200	2325	300	0,3370167742
1000	50	2400	240	0,3225806452
900	50	2700	320	0,2903225806
$\Sigma$ 3100				

}  $\Rightarrow \frac{N_i}{N} = w_i$

a)  $\bar{x}_{st} = w_i \cdot \bar{x}_i = 0,337... \cdot 2325 + 0,322... \cdot 2400 + 0,290... \cdot 2700 = 1093,548387 + 774,1935484$

$+ 785,8202672 = 2651,612903$  R

$V(\bar{x}_{st}) = w_i \cdot \frac{S_i^2}{n} \cdot \left(1 - \frac{n}{N}\right) = \frac{1200}{3100} \cdot \frac{300^2}{200} \cdot \left(1 - \frac{200}{3100}\right) + \frac{1000}{3100} \cdot \frac{240^2}{50} \cdot \left(1 - \frac{50}{1000}\right) + \frac{900}{3100} \cdot \frac{320^2}{50} \cdot \left(1 - \frac{50}{900}\right)$

$\Rightarrow 50,19146722 + 160,274738 + 163,0301764$

$\Rightarrow 355,4963579$  R

95% -igt CI

från tabell

$\bar{x} \pm Z_{\alpha/2} \cdot \sqrt{V(\bar{x})} = 2651,612903 \pm 1,96 \cdot \sqrt{355,4963579}$

$2651,612903 \pm 38,48275989$

$[2613,130143; 2690,095663]$  R

S.D.: Med 95% konfidens ligger det sanna värde i intervallet ovan. R



## UPPGIFT 4 FORTSÄTTNING

b) Optimal allokering  $\Rightarrow \frac{N_i \cdot \sigma_i}{\sum N_j \cdot \sigma_j} \cdot n$ 

$$1200 \cdot 350 = 420000$$

$$1000 \cdot 200 = 200000$$

$$900 \cdot 300 = 270000$$

$$\Sigma 890000$$

$$\frac{420000}{890000} \cdot 300 = 141,57 \approx \underline{142}$$

$$890000$$

$$\frac{200000}{890000} \cdot 300 = 67,4157 \approx \underline{68}$$

$$890000$$

$$\frac{270000}{890000} \cdot 300 = 91$$

$$890000$$

$$142 + 68 + 91 + 300$$

c) Proportionell allokering

$$n_i = n \cdot \frac{N_i}{N}$$

$$300 \cdot \frac{1200}{3100} = 116,12 \approx \underline{116}$$

$$300 \cdot \frac{1000}{3100} = 96,77 \approx \underline{97}$$

$$300 \cdot \frac{900}{3100} = 87,09 \approx \underline{87}$$

$$116 + 97 + 87 = 300$$

Urvalet dras proportionellt från populationen

vänd  $\Rightarrow$  blad

Man kan dra urvalen på tre olika

Sätt	Eronpnr	Lärare	Jurister
Pop	0,3	0,6	0,2
Urval	0,3	0,6	0,2

} Proportionellt

Eller så kan man dra lika ur alla urval

	Eronpnr	Lärare	Jurister
pop	500	1000	100
urval	50	50	50

}  $n=150$   
lika i varje  $n_i$

Eller så kan man göra optimal  
allokering  $\sigma = \sqrt{p(1-p)}$  och då behöver  
man standardavvikelsen för varje stratum.

### UPPGIFT 5

$$1,96 \cdot \frac{\sqrt{p(1-p)}}{n} \leq 0,03 \quad | \cdot n$$

1. Vi använder oss av största möjliga varians

$$0,5 \cdot 0,5 = 0,25$$

$$1,96 \cdot \frac{\sqrt{0,25}}{n} \leq 0,03$$

$$2. \quad 1,96^2 \cdot \frac{0,25}{n} \leq 0,03^2$$

$$3. \quad 1,96^2 \cdot 0,25 \leq 0,03^2 \cdot n$$

$$4. \quad \frac{1,96^2 \cdot 0,25}{0,03^2} \leq n$$

$$5. \quad \frac{0,9604}{0,0009} = n$$

$n = 1067,1111$  Man avrundar alltid  
uppåt så svar  $n = 1068$